

PATENT ABSTRACTS OF JAPAN

(11)Publication number : 11-143486
 (43)Date of publication of application : 28.05.1999

(51)Int.CI. G10L 3/00
 G10L 3/00
 G10L 3/00

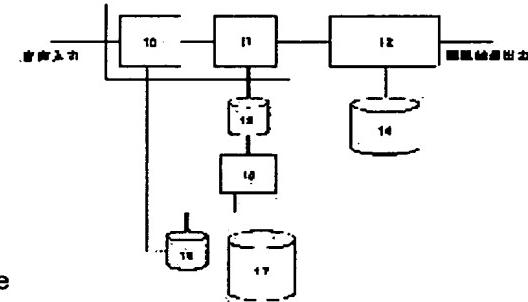
(21)Application number : 09-306887 (71)Applicant : FUJI XEROX CO LTD
 (22)Date of filing : 10.11.1997 (72)Inventor : SUMIYA KAZUHIKO
 SAITO NOBUYUKI

(54) DEVICE AND METHOD ADAPTABLE FOR SPEAKER

(57)Abstract:

PROBLEM TO BE SOLVED: To realize the speaker-adaptable capacity excellent in accuracy in the speaker adaptation using the maximum posterior probability estimating method.

SOLUTION: A set 17 of a large number of speaker models independent from an adaptable speaker is prepared using an acoustic analyzing means equivalent to an acoustic analysis part 10. Then, the sound of the adaptable speaker is inputted, and analyzed by the acoustic analysis part 10, the distribution of the feature parameter vector of the adaptable speaker is obtained, and preserved as the sample data 16 for adaptation. An adaptable model preparation part 15 measures the distance between the adaptable speaker model preserved as the sample data 16 for adaptation and a large number (N-pieces) of speaker models preserved as the set 17 of the speaker model, and the speaker models of M pieces are selected in the order of smaller distance to the adaptable speaker model. The weighted addition of the selected speaker models of M pieces is achieved to determine the initial model.



LEGAL STATUS

[Date of request for examination]

[Date of sending the examiner's decision of rejection]

[Kind of final disposal of application other than the examiner's decision of rejection or application converted registration]

[Date of final disposal for application]

[Patent number]

[Date of registration]

[Number of appeal against examiner's decision of rejection]

This Page Blank (uspto)

[Date of requesting appeal against examiner's
decision of rejection]

[Date of extinction of right]

Copyright (C); 1998,2003 Japan Patent Office

This Page Blank (uspto)

(19)日本国特許庁 (JP)

(12) 公開特許公報 (A)

(11)特許出願公開番号

特開平11-143486

(43)公開日 平成11年(1999)5月28日

(51)Int.Cl. ⁶ G 1 0 L 3/00	識別記号 5 3 5 5 2 1 5 3 1	F I G 1 0 L 3/00	5 3 5 5 2 1 F 5 3 1 F 5 3 1 K
--	---------------------------------	---------------------	--

審査請求 未請求 請求項の数4 O.L (全10頁)

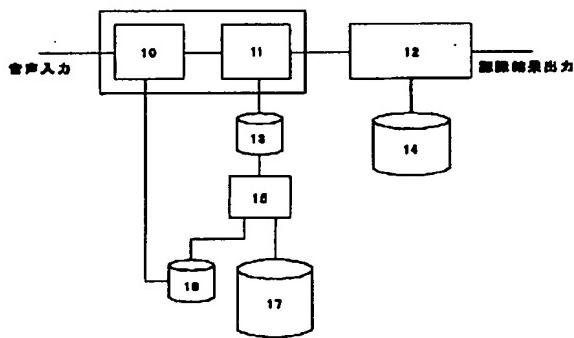
(21)出願番号 特願平9-306887	(71)出願人 富士ゼロックス株式会社 東京都港区赤坂二丁目17番22号
(22)出願日 平成9年(1997)11月10日	(72)発明者 住谷 和彦 神奈川県足柄上郡中井町境430 グリーン テクなかい 富士ゼロックス株式会社内
	(72)発明者 斎藤 伸行 神奈川県足柄上郡中井町境430 グリーン テクなかい 富士ゼロックス株式会社内
	(74)代理人 弁理士 澤田 傑夫

(54)【発明の名称】 話者適応装置および方法

(57)【要約】

【課題】 最大事後確率推定法を用いた話者適応において、精度の高い話者適応の能力を実現する。

【解決手段】 音響解析部10と同等の音響解析手段を使って、適応対象話者と独立した多数の話者モデルの集合17を用意する。次に、適応対象の話者の音声を入力し、音響解析部10で分析して適応対象話者の特徴パラメータベクトルの分布を求め、適応用サンプル・データ16として保存する。適応モデル作成部15では、適応用サンプル・データ16として保存されている適応対象の話者モデルと話者モデルの集合17として保存されている多数(N個)の話者モデルとの間の距離を測定し、適応対象の話者モデルとの距離が近い順にM個の話者モデルを選ぶ。そして、選択したM個の話者モデルの重み付き加算値を行い初期のモデルを決定する。



【特許請求の範囲】

【請求項1】 初期話者モデルと適応学習用データとを用いて、最大事後確率推定法によって話者モデルのパラメータを再推定し、話者適応を行う話者適応装置において、事前に、多数の話者から多数の初期話者モデルを作成し、適応対象の話者が発声した適応用学習データから、その適応対象話者の特徴を抽出し、前記多数の初期話者モデルの中から、前記適応対象話者の特徴に距離的に最も近い方からN個の話者モデルを選択し、選択されたN個の話者モデルの各々を事前に仮定された分布として、適応用学習データを使って話者モデルのパラメータを推定し、その推定されたパラメータを持つN個の話者モデルを混合加算することにより適応対象話者の音声モデルを作成することを特徴とする話者適応装置。

【請求項2】 混合するN個の話者モデルは、適応対象話者の特徴ベクトルとの距離に応じて、重み付けされることを特徴とする請求項1記載の話者適応装置。

【請求項3】 適応対象の話者と距離的に最も近い話者モデルとの距離を基底距離とするとき、適応対象の話者との距離が前記基底距離と比較して一定範囲以内である話者モデルを選択することにより、混合する話者モデルの個数Nを可変とすることを特徴とする請求項1または2記載の話者適応装置。

【請求項4】 初期話者モデルと適応学習用データとを用いて、最大事後確率推定法によって話者モデルのパラメータを再推定し、話者適応を行う話者適応方法において、事前に、多数の話者から多数の初期話者モデルを作成し、適応対象の話者が発声した適応用学習データから、その適応対象話者の特徴を抽出し、前記多数の初期話者モデルの中から、前記適応対象話者の特徴に距離的に最も近い方からN個の話者モデルを選択し、選択されたN個の話者モデルの各々を事前に仮定された分布として、適応用学習データを使って話者モデルのパラメータを推定し、その推定されたパラメータを持つN個の話者モデルを混合加算することにより適応対象話者の音声モデルを作成することを特徴とする話者適応方法。

【発明の詳細な説明】

【0001】

【発明の属する技術分野】 本発明は、適応対象話者が発声した音声を学習用データとして、初期の音声モデルを修正し、話者に適応させた音声モデルを作成する、話者適応技術に関する。

【0002】

【従来技術】 隠れマルコフモデル（Hidden Markov Model、以降HMMと略す）は、音声のスペクトル的、時間的な変動に対処しやすく、高い認識精度を実現できることから、音声認識において広く用いられている。HMMは、状態間の遷移確率、状態遷移に伴うシンボルの出力確率を持った状態遷移モデルであり、音声信号のような時間とともに連続的に変化する信

号をモデル化するには、左から右に状態が遷移する、所謂left-to-right型モデルが適當である。図1に状態数4の場合のleft-to-right型HMMの例を示す。ここで、1, 2, 3, 4は状態を表し、 a_{ij} ($i, j = 1, \dots, 4$) は、状態 i から状態 j に遷移する確率を示している。また、 $b_j(o)$ は、状態遷移に伴って状態 j においてシンボル o が観測される確率を示している。音声認識の場合、このシンボルとしては、通常、特徴パラメータベクトルが使われる。

【0003】 HMMを使った音声認識では、認識の対象となる音声の単位（例えば、音素、音韻、音節、単語）ごとに、HMMによる音声モデルを用意し、事前に訓練用の音声データを用いて、状態遷移確率 a_{ij} 、特徴パラメータベクトルの出力確率 $b_j(o)$ といったモデル・パラメータを決定しておく。そして、認識時には、入力された音声を分析し、特徴パラメータベクトルの系列に変換し、そのパラメータベクトルの系列を観測する可能性が最も高くなるモデルに対応する音声単位の列を決定し、それを認識結果とする。

【0004】 HMMのような統計モデルでは、一般に、学習用のデータを増やすことにより、モデルの精度を高めることができる。そこで、対象となる話者が発声した大量のデータを用いることによって、その話者のための精度の高いモデルを作成することができる。しかし、そのためには、使用に先立って大量の音声データを収集する必要があり、そのためには話者に大量の発声を要求することになり、実用上の障害になっていた。

【0005】一方、事前に不特定多数の話者の音声データを収集し、それに基づいて、話者に依存しない標準的な話者モデルを作ることが考えられる。この不特定話者を対象としたモデルを用いれば、使用者が使用に先立って話者モデルを訓練するために大量の発声を行う必要がなく、すぐに使用を開始できるという利点がある。しかし、話者ごとに適合させたモデルではないので、認識精度が十分ではない。一般に、音声認識では、個人に即した音声モデルを用意することにより、認識の精度を高めることができるが、その音声モデルを作成するためには多数の発話を事前に用意する必要があり、認識精度と手間がトレードオフの関係になっている。

【0006】こうしたことから、少量の話者固有の発声データだけで、使用を開始することができ、さらに話者固有の発声データを追加することによって逐次的に認識精度を向上させる事を狙った「話者適応」が、音声認識を応用するある局面では注目されている。例えばディクテーションのような、ある程度個人的に使用されるものでは、簡単な手続きで使用することができ、また、使用について、逐次、認識の精度が向上していくことが望ましく、この話者適応が有効であろう。

【0007】「話者適応」の手法の一つとして、予め求めておいた初期の音声モデルを、実際の話者や使用環境

の特徴を取り込んで、修正することによって実現する手
法があり、その中でも、ベイズ推定に基づいた音声モ
デルのパラメータの再推定が試みられ、効果をあげてい
る。ベイズ推定は、ベイズの定理に基づいて、パラメー
タを決定するものであり、以下の考え方による。

【0008】ある事象Aという結果を生じさせた原因H_i
の可能性P(H_i|A)は、ベイズの定理により、原因
の確率P(H_i)に、その原因からある事象が発生する
確率P(A|H_i)をかけたものによって計算される。
この時、P(H_i)は事前確率とよばれ、P(H_i|A)
は事後確率と呼ばれる。つまり、事前に予測した事前確
率P(H_i)とサンプルの確率P(A|H_i)によって事
後確率が決定すると考える。

【0009】原因として分布のパラメータをとり、結果
としてサンプルされるデータをとる。そうすると、分布
のパラメータの事後確率は、分布のパラメータの予測値
である事前確率とサンプルデータから得られる結果の確
率から得られることになる。そこで、モデルのパラメー
タについての正しい予測があれば、事後確率の決定にそ
れを効果的に取り込むことができる。

【0010】一般に、結果の確率に対して、事前確率と
事後確率が同一の分布族に属していれば、サンプルは分布
族内の変換を起こすだけであり、数学的な取り扱いが
容易になる。このときの事前確率と事後確率の分布族
は、自然な共役分布と呼ばれるが、ガウス分布N(θ, *

(文章中の表記の制限により「o」を「o」で表すこともある。)

で与えられる。ここで、nは対応するHMMの状態において観測される訓練用サンプルの個数、oはサンプルの平均である。つまり、平均値の最大事後確率推定法による推定値は、事前分布の平均値vとサンプルの平均oの重み付き平均で与えられる。(1)から明らかに、nが0のとき、つまりサンプルが全くない場合には、推定値は事前分布の平均値vのままである。また、nが十分大きいとき、つまり、サンプル数が十分多いときは、推定値はサンプルの平均oに近づく。このように、最大事後確率推定法では、事前に予測した分布を取り込んで、サンプルデータの個数に応じてモデルのパラメータを訓練用サンプルの特性に漸近的に近づけることができるので、使用に応じて逐次話者モデルの精度向上を図ることができ、理想的な話者適応を実現できる。

【0013】文献1では、ベイズ推定による他のパラメー
タに対する話者適応例として、分散の場合と平均と分
散双方の場合についても述べられているが、平均値の話
者適応が認識性能に対して効果が高いことが示されてい
る。

【0014】

【発明が解決しようとする課題】この最大事後確率推定
法によるパラメータ推定を使った話者適応方式が、これ
までに開示されている。特開平8-95592号公報で
開示されている従来例1では、標準的音素モデルを用い

* σ^2 の平均のパラメータθについて、ガウス分布N
(λ , τ^2) は自然な共役分布であることが知られて
いる。

【0011】ベイズの定理に基づく枠組みの中で、パラ
メータを推定し話者適応を行う方法が、最大事後確率推
定法として、例えば、Chin-Hui Lee, Chi-heng Lin and Biing-Hwa
ng Juang, "A Study on Speaker Adaptation of the Par
10 ameters of Continuous Den
sity Hidden Markov Model
s", IEEE Transactions on Signal Processing, Vol. 39, No. 4, April, 1991 (以後文献1とする)
で、開示されている。これによれば、平均値パラメータ
 μ が事前確率P₀(μ)に従い、その分散 σ^2 が既知で固
定とすると、 μ の共役な事前分布は、平均値v、分散 τ^2
を持ったガウス分布であり、これを使うと、パラメー
タの最大事後確率推定値は、

20 【0012】

【数1】

$$\mu_{MAP} = \frac{n\tau^2}{\sigma^2 + n\tau^2} \bar{o} + \frac{\sigma^2}{\sigma^2 + n\tau^2} v \quad (1)$$

て、ある特定の話者に音素モデルを合わせ込む話者適応
を行っているが、標準的な初期音声モデルとしては、老
若男女いろいろな話者が発声した音声データを用いて予
め学習しておいた、不特定多数の話者の音声を認識対象
とした不特定話者モデルを用いるとしている。この従来
例1で示している不特定話者モデルを用いた適応方式で
は、事前分布として用いる標準的な初期音声モデルの分
布が広がっており、少量の学習データで、それを十分に
補償し、適応対象の話者に適応するようパラメータを補
正することは困難である。

【0015】また、特開平8-110792号公報で開
示されている従来例2では、木構造クラスタリングモ
デルにより作成した話者クラスタを用いて初期話者モ
40 デルを作成するとしている。この方法では、初期話者モ
デルの分布をある程度絞る事ができるが、クラスタの中心が
適応対象となる話者モデルのベクトルの中から、大き
くずれている場合には、補正の効果が小さく、十分な適応
ができない恐れがある。

【0016】最大事後確率推定法は、前述したように、
話者の発声サンプルデータを用いて、初期話者モ
デルのパラメータを修正し、話者に適応させていくもので、サ
ンプルデータの数に応じて漸次モデルの精度を向上させ
ることができるが、この初期の話者モデルをどう選ぶか
が、適応の能力に大きく影響する。本発明は、こうした

5
点に鑑みなされたもので、最大事後確率推定法を用いた話者適応において、精度の高い話者適応の能力を実現するための手段を与えるものである。本発明は、最適な初期の話者モデルを選択することにより、適応対象の特定の話者からの少量の发声データを用いて、その話者に対する精度の高い音声モデルを作成する話者適応装置を実現することを目的とするものであり、その話者適応装置を用いることにより、精度の高い話者適応の能力を持った音声認識装置を実現することができる。

【0017】

【課題を解決するための手段】本発明は、初期話者モデルと適応学習用データを用いて、最大事後確率推定法によって話者モデルのパラメータを再推定し、話者適応を行う装置において、多数の話者から作成した多数（N個）の話者モデルを事前に用意し、それらの多数の話者モデルの中から、適応対象の話者に距離的に近いM個の話者モデルを選択し、そして選択されたM個の話者モデルを混合して初期の話者モデルを構成することを特徴とする。また、そのとき、個数M（M<<N）を適応対象話者と事前に用意されたN個の個々の話者モデルとの距離の関係に基づいて決定する。これにより、分布に応じた精度の高い初期モデルを決定することができるとともに、不必要的パラメータの増加を押さえることができる。

【0018】この構成においては、混合するN個の話者モデルは、適応対象話者の特徴ベクトルとの距離に応じて、重み付けされるようにしてもよい。

【0019】また、適応対象の話者と距離的に最も近い話者モデルとの距離を基底距離とするとき、適応対象の話者との距離が前記基底距離と比較して一定範囲以内である話者モデルを選択することにより、混合する話者モデルの個数Nを可変とするようにしてもよい。

【0020】また、本発明は方法としても実現でき、また少なくともその一部をコンピュータプログラム製品としても実現できる。

【0021】

【発明の実施の態様】以下、本発明の実施例について説明する。

【0022】図2は、本発明による話者適応装置とそれを用いた音声認識システムの実施例をブロック図で示したものである。音声認識システムは、入力された音声を音響解析部10で分析し、特徴パラメータ・ベクトルの系列を抽出する。抽出した特徴パラメータ・ベクトルの系列を、音韻照合部11において、言語モデル14からの粗い情報を参照しながら、音声モデル13と照合し、複数の音韻系列の候補を作成する。こうしてできた複数の音韻系列の候補を、言語認識部12で言語モデル14からの細かい情報を使って再評価し、最終的な認識結果を確定する。上記の話者に適応した音声モデル13を作る手段が本発明による話者適応化装置であり、その方法

と構成を以下に述べる。

【0023】この実施例では、まず、事前に多数の話者の音声を収集し、図示していない、音響解析部10と同等の音響解析手段を使って、適応対象話者と独立した多数の話者モデルの集合17を用意しておく。つまり、N人の話者の音声を収集することにより、N個の分布を予め計算して用意しておく。図3は、これらの多数の話者モデルの特徴パラメータベクトルの出力確率分布を模式的に破線で示したものである。説明の都合上、特徴パラ

- 10 メータベクトルを2次元として表示しているが、この特徴パラメータベクトルは、実際には30次元程度の多次元ベクトルとするのが普通である。各話者モデルは、図3に示すように、相互に重なり合いながら、多次元空間内に分布している。次に、話者適応のために、適応対象の話者の音声を入力し、音響解析部10で分析して適応対象話者の特徴パラメータベクトルの分布を求め、適応用サンプル・データ16として保存する。図4は、この適応用サンプル・データから得られた適応対象話者の特徴パラメータベクトルの出力確率の分布の様子の例を実線で示したもので、先に求めた多数の特定話者モデルの分布との関係を示したものである。以上のようにして適応対象の話者モデルと多数（N個）の話者モデルとを決定しておき、適応モデル作成部15において、適応化した音声モデル13を作成する。それは次の手順で行う。適応モデル作成部15では、まず適応用サンプル・データ16として保存されている適応対象の話者モデルと話者モデルの集合17として保存されている多数（N個）の話者モデルとの間の距離を測定する。話者モデルとして、多変量のガウス分布を仮定すると、この距離としては、適応対象の話者モデルの中心ベクトルと特定話者モデルとのマハラノビス距離を用いることができる。この距離を使って、適応対象の話者モデルとの距離が近い順にM個の話者モデルを選ぶ。図4は、Mを3とした場合について、適応対象の話者モデルの最近傍にある、n番目、n+1番目とn+2番目のモデルが選ばれる様子を説明している。こうして、M個の話者モデルが選択できると、それらの重み付き加算値として初期のモデルを決定する。

- 【0024】なお、この時の重みをこれらの距離に基づいて決定することができる。

- 【0025】また、混合するモデルの個数Mを固定値とせず、分布に応じて変化させるようにしてもよい。初期モデルの候補として選択するモデルが不確かな場合は、混合するモデルの個数Mを多くし、確かな場合は混合するモデルの個数Mを少なくする。そのために、適応対象の話者モデルの中心ベクトルとN個の特定話者モデルとのマハラノビス距離を測定し、その距離が、全モデルに対する距離の中で最も短いものと比べてある一定範囲内であるモデルを選ぶ。こうして選ばれたモデルの個数を50 M個であるとき、先の例と同様にしてM個のモデル

の重み付き加算による混合で初期のモデルを作成する。このときも、先の例と同様に、重みはこれらの距離に基づいて決定することができる。こうすることによって、曖昧性が強い、不確かな初期モデルの候補に関しては、混合数を多くして細かいモデルを作成し、逆に、曖昧性が低く、確度の高い初期モデルの候補に関しては、混合数を少なくして計算量を削減したモデルを作ることができる。上記の一定範囲内としては、適応対象の話者モデルの中心ベクトルと全モデルに対する距離の中で最も短いものを D_{min} とするとき、その距離と D_{max} の比が一定値以下のもの、或いは、その距離と D_{max} の差が一定値以下のものを選べばよい。

【0026】以下に具体例について詳しく述べる。

【0027】[具体例1] ここでは、連続音声認識に対応した話者適応方式を例として示す。連続音声認識のためには、認識の単位となる音声の単位を音素レベルとするのが適当である。そこで、ここでは、音素毎にHMMを作成する。HMMの作成は、音声データを使ってHMMのパラメータを決定する訓練と呼ばれる手続きを実行することにより行われる。連続的に発声された発声データを用いて音素レベルのHMMを訓練するには、発声された音素列に関して、先行する音素のHMMの最終状態を後続する音素のHMMの初期状態につなげて訓練を行う。

【0028】本発明を実施するためには、事前に多数の話者からの発声データを収集し、認識単位となる音声単位毎にHMMを作成する必要がある。音声信号のような時間とともに連続的に変化する信号をモデル化するに *

$$a_{ij} = \frac{\text{状態 } i \text{ から状態 } j \text{ に遷移する回数の期待値}}{\text{状態 } i \text{ から遷移する回数の期待値}} \quad (3)$$

$$b_j(o) = \frac{\text{状態 } j \text{ でベクトル } o \text{ を観測する回数の期待値}}{\text{状態 } j \text{ にある回数の期待値}} \quad (4)$$

として、パラメータを再推定し、推定されたパラメータを入れ替えて推定の計算を繰り返すことにより、 o が観測される確率が極大となるようなモデルを作成することができる。

【0032】このとき、 $b_i(o)$ として、式(2)の *

$$\mu_j = \frac{\sum_{t=1}^T \gamma_t(j) \cdot o_t}{\sum_{t=1}^T \gamma_t(j)} \quad (5)$$

$$\Sigma_j = \frac{\sum_{t=1}^T \gamma_t(j) \cdot (o - \mu_j)(o - \mu_j)^T}{\sum_{t=1}^T \gamma_t(j)} \quad (6)$$

* は、前述したように、左から右に状態が遷移する、所謂 left-to-right型のHMMが適当であるので、図1のような、例えば4状態のHMMを使用する。図1において、1, 2, 3, 4は状態を表し、 a_{ij} ($i, j = 1, \dots, 4$) は、状態 i から状態 j に遷移する確率を示している。状態 j において、モデルから観測される事象を $b_i(o)$ であらわす。この観測事象の対象である音声の特徴パラメータベクトルは、連続信号であるので、 $b_i(o)$ は以下のようない連続確率密度関数で表すことができる。

【0029】

【数2】

$$b_j(o) = N[\mu_j, \Sigma_j] \quad (2)$$

ここで、 o は観測ベクトル、 $N[\dots]$ は、平均値ベクトル μ_j 、分散・共分散行列 Σ_j のガウス分布関数である。

【0030】個々のモデルにおけるパラメータ、 a_{ij} ($i, j = 1, \dots, 4$) や $b_i(o)$ ($j = 1, \dots, 4$) は、公知の Baum-Welch 法を使った繰り返し計算により求めることができる。この Baum-Welch 法による再推定については、文献、Lawrence Rabiner, Biing-Hwang Juang, "Fundamentals of Speech Recognition", Prentice Hall PTR 93で詳しく述べられている。その概要を示すと以下の通りである。Baum-Welch 法では、

【0031】

【数3】

※ ようなガウス分布を仮定すると、 μ_j 、 Σ_j に対する再推定の式は、

【0033】

【数4】

となる。ここで、 $\gamma_t(j)$ は、観測系列 \circ とモデルが与えられたとき、時刻 t において状態 j に存在する確率である。以上のようにして、事前に作成しておく、複数の話者のモデルが決定する。

【0034】適応は、以下のステップで行う。まず、適応対象話者から適応学習用の音声データを収集する。そして、これらの適応用学習データに含まれる各音素のHMMについて、上述した方法に従い、パラメータを決定する。そのとき、ビタビ・セグメンテーションにより、音素のHMMの各状態に対応するフレームが決まっているので、それによって、適応学習用データのサンプル数が求められる。

$$D_{kj}^2 = (\mu_{kj} - \mu_j) \Sigma_{kj}^{-1} (\mu_{kj} - \mu_j)' \quad (7)$$

で求められる。ここで、 Σ_{kj}^{-1} は、分散・共分散行列 Σ_{kj} の逆行列、 $(\mu_{kj} - \mu_j)'$ はベクトル $(\mu_{kj} - \mu_j)$ の転置ベクトルである。

【0038】すべての話者モデルに対してマハラノビス距離 D_{kj} を計算し、距離の近い方からM個の話者のモデルを選択する。図4は、これを説明するため、Mが3のときの様子を示したもので、距離の近い方から3つのモデル、n、n+1、n+2が選ばれている。但し、状態に関する添字は省略している。

【0039】さて、この選択されたM個の話者モデルの中の、m ($1 \leq m \leq M$) 番目の話者モデルの特徴ベクトル \ast

$$\mu_{mj}^{MAP} = \frac{n\tau_{mj}^2}{\sigma_j^2 + n\tau_{mj}^2} o_m + \frac{\sigma_j^2}{\sigma_j^2 + n\tau_{mj}^2} \mu_{mj} \quad (8)$$

で与えられる。ここで、n はサンプルの個数である。

【0041】つまり、m ($1 \leq m \leq M$) 番目の話者モデルを初期モデルとした、特徴ベクトルのある要素の平均の推定値は μ_{mj}^{MAP} 、事前分布の平均値 μ_{mj} と、適応学習において観測されたサンプルの平均 o_m の重み付き平均となる。

【0042】そこで、m番目の話者モデルに対して得られた推定値を用いて、適応対象話者に対するモデルは、次の形で与えられる。

【0043】

【数7】

$$b_j(o) = \sum_{m=1}^M c_{mj} N[o, \mu_{mj}^{MAP}, \Sigma_{mj}] \quad (9)$$

ここで、 c_{mj} は、話者モデルの j 番目の状態における、m番目の話者に対する重みの係数で、これは、前記の過程の中で計算されている距離に基づいて決定することができる。つまり、

【0044】

【数8】

* 【0035】次に、学習データから得られた、適応対象話者のモデルと、事前に得られている多数の話者モデルとの距離を計算する。この距離としては、平均値ベクトルと話者モデルとのマハラノビス距離を使う。

【0036】ある k 番目の話者モデルの j 番目の状態の分布の平均値ベクトルが μ_{kj} 、分散・共分散行列が Σ_{kj} であるとし、適応対象話者の j 番目の状態の平均値ベクトル μ_j とこの k 番目のモデルのマハラノビス距離を D_{kj} とするとき、 D_{kj} の二乗は

10 【0037】

【数5】

*

※ルを考える。そしてその特徴ベクトルのある要素の平均を μ_{mj} 、その分散を σ_{mj}^2 とする。今、特徴ベクトルの要素の平均 μ_{mj} が、事前分布 $P(\mu)$ を持ち、その分散 σ_{mj}^2 が既知の固定値であるとする。そうすると、 μ_{mj} に対する共役な事前分布は、ガウス分布となる。そこで、m ($1 \leq m \leq M$) 番目の話者モデルを平均に対する共役事前分布とすると、最大事後確率推定法により、平均の推定値 μ_{mj}^{MAP} は、

【0040】

【数6】

20

$$c_{mj} = \frac{1}{D_{mj}} \quad (10)$$

$$\sum_{m=1}^M c_{mj} = 1 \quad (11)$$

とすればよい。このとき、あきらかに

【0045】

【数9】

40 であり、(9) のは統計的制約を満足するように決定されている。

【0046】[具体例2] 具体例1では、モデルの混合数Mを固定したが、このMの値をモデルの分布に応じて変化させることにより、計算コストに対して適応能力が高い、効率的なモデルを作成する事ができる。つまり、適応対象の話者モデルの中心ベクトルと事前に用意されている多数の特定話者モデルとの距離の分布が、状態ごとに違い、一様ではないときには、その確からしさに応じて、Mの値を変化させるのである。例えば、適応対象の話者モデルの中心ベクトルと事前に用意されている多

50

11

数の話者モデルとの距離が、それぞれの話者モデル間で大きく異なり、少數の話者モデルのみに近いときには、それらのモデルのみを混合する分布として利用すれば十分であり、そうすることにより、無駄なパラメータの増加を防ぐことができるからである。

【0047】具体例2では、適応対象話者のモデルと事前に得られている多数の話者モデルとのマハラノビス距離 D_k をとり、それに基づいて混合数を決定する。本発明を実施するためには、まず、具体例1と同様にして、事前に多数の話者からの発声データを収集し、認識単位となる音声単位毎に多数の話者のHMMを作成する。次に、適応対象話者から適応用学習用の音声データを収集し、適応用学習データに含まれる各音素のHMMについて、モデルのパラメータを決定する。そして、こうして得られた適応対象話者のモデルと、多数の話者モデルとの距離を計算する。距離としては、マハラノビス距離を使う。この具体例2では、適応対象話者のモデルと、多数の話者モデルとの距離のうち最少のものを

【0048】

【数10】

$$D_{min} = \min_{1 \leq m \leq M} D_m \quad (12)$$

とするとき、 D_{min} と比較して規定の範囲の距離 D_k をもつモデル k のみを混合する要素として選択する。

【0049】この様子を図で説明すると以下のようになる。例えば、図5のように、モデル n に対する距離 D_n が最少であり、モデル $n+1$ 、モデル $n+2$ に対する距離 D_{n+1} 、 D_{n+2} がその最少距離と比較してある範囲以内であれば、モデル n 、モデル $n+1$ 、モデル $n+2$ の3つのモデルが、混合するモデルとして選ばれる。また、例えば、図6のように、モデル n に対する距離が最少であり、モデル $n+1$ に対する距離はと比較してある範囲以内あるが、その次に近いモデル $n+2$ に対する距離が*

$$c_{mj} = \frac{\frac{1}{D_{mj}}}{\sum_{m=1}^{M'} \frac{1}{D_{mj}}} \quad (16)$$

とすればよい。

【0057】

【発明の効果】本発明は、事前に仮定した初期話者モデルと適応用学習用データを用いて、最大事後確率推定法によって話者モデルのパラメータを再推定し、話者適応を行う装置において、初期話者モデルとして適応対象の話者の特性にできるだけ近いと考えられる予測分布を仮定しようとするものである。初期話者モデルに適応対象の話者の特性にできるだけ近い予測分布を用いることにより、少量の適応用学習用データで精度の高いモデルのパラメータ推定が行われ、良好な話者適応が実現する。本発

10

12

*と比較してある範囲以内なければ、モデル n とモデル $n+1$ の2つのモデルのみが混合するモデルとして選択される。

【0050】この最少距離と比較してある範囲を決定する方法としては、モデル k との距離 D_k と最少距離 D_{min} との比が、一定値 δ 以下である、つまり

【0051】

【数11】

$$\frac{D_k}{D_{min}} < \delta \quad (13)$$

なる k 番目のモデルを選択するのが一つの方法である。

【0052】また、モデル k との距離 D_k と最少距離 D_{min} との差が一定値 δ' 以下である、つまり

【0053】

【数12】

$$|D_k - D_{min}| < \delta' \quad (14)$$

なる k 番目のモデルを選択する事もできる。

【0054】いずれかの方法で、選択されたモデルの個数を M' とするとき、それらの選択された話者モデルに対して得られた推定値を用いて、適応対象話者に対するモデルは、具体例1の場合と同様にして次の形で与えられる。

【0055】

【数13】

$$b_j(o) = \sum_{m=1}^{M'} c_{mj} N[o, \mu_{mj}^{MAP}, \Sigma_{mj}] \quad (15)$$

ここで、 c_{mj} は、話者モデルの j 番目の状態における、 m 番目の話者に対する重みの係数で、これは、前記の過程の中で計算されている距離に基づいて決定することができる。つまり、

【0056】

【数14】

【0058】明では、事前に得られている多数の特定話者モデルと適応対象話者の距離を測定し、距離的に近い N 個のモデルを選択的に用いることによりこの作用を効果的に発現させる方法を開示しており、これにより高い適応性を実現する事ができる。

【0059】また、本発明では、距離的に近い M 個のモデルを選択するときに、モデルとの距離の相対的な関係により、選択するモデルの個数 M を変化させる方法を開示している。これは、仮定する予測分布の分布に応じて最適な混合モデルを選択するもので、これにより、最良の適応能力が發揮されるとともに、計算処理量も減少す

50

るという効果もある。

【図面の簡単な説明】

【図1】 HMMの例を示す模式図である。

【図2】 本発明の実施例を示すブロック図である。

【図3】 多数の特定話者モデルの分布の例を示す図である。

【図4】 学習データから得られる適応対象話者の分布の例を示す図である。

【図5】 適応対象話者モデルの最近傍にある特定話者モデルの分布の例を示す図である。

【図6】 適応対象話者モデルの最近傍にある特定話者モデルの分布の他の例を示す図である。

* 【符号の説明】

1~4 HMMの状態

10 音響解析部

11 音韻照合部

12 言語認識部

13 音声モデル

14 言語モデル

15 適応モデル作成部

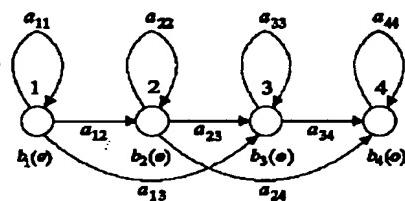
16 適応用サンプル・データ

10 17 特定話者モデルの集合

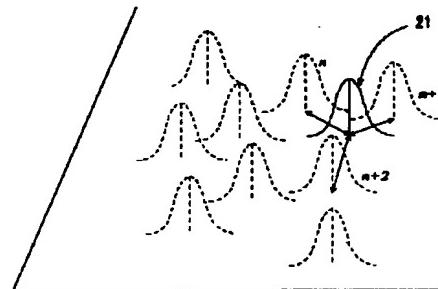
20 多数の話者の特徴ベクトルの分布

* 21 適応対象話者の特徴ベクトルの分布

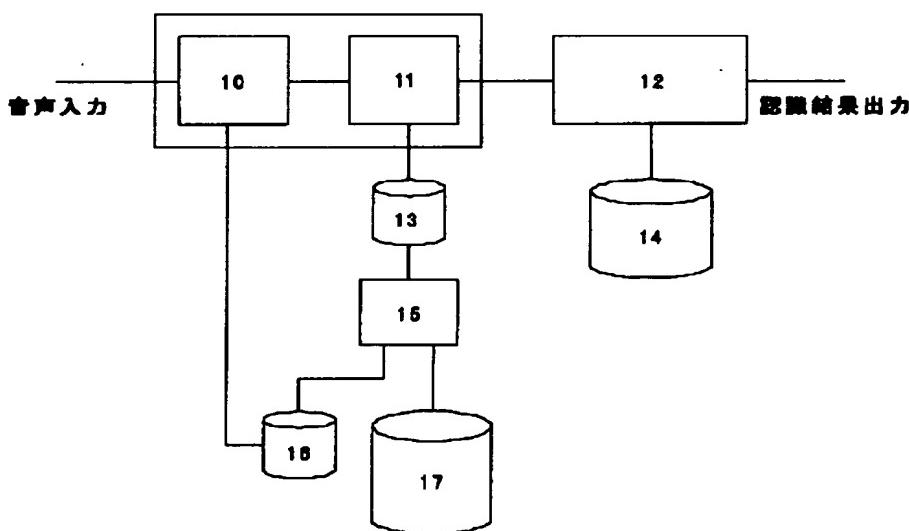
【図1】



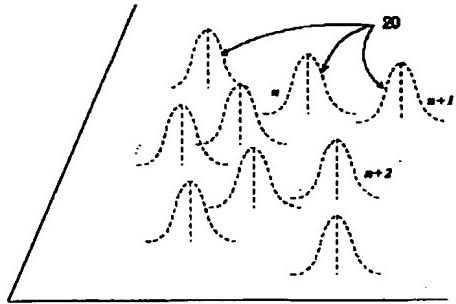
【図4】



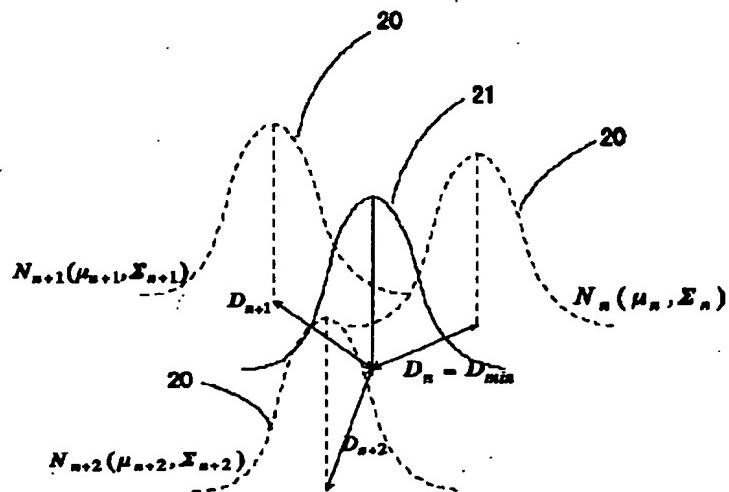
【図2】



【図3】



【図5】



【図6】

